

## Processos de Lévy em Finanças

Prf. José Fajardo Barbachan  
IBMEC Business School

Evento Oppencad, 18 de Agosto de 2004

---

---

---

---

---

---

---

---

## Toolbox Estatístico

- Norminv,tinv, binoinv,betainv, chi2inv
- Normcdf, normpdf,tcdf,tpdf,chi2cdf,chi2pdf, F, .
- Expcdf,exppdf,expfit,expinv
- Gamcdf,poisscdf,etc
- Normfit, tfit
- Hist(rettnlp4); histfit(rettnlp4)

---

---

---

---

---

---

---

---

## Toolbox Estatístico

- Cov
  - Kurtosis
  - Skewness
  - Mean,std
- Normalidade*
- qqplot( rettnlp4,retnorm)
  - jbtest, kstest, lillietest,( rettnlp4,rettnlp4)

---

---

---

---

---

---

---

---

## Toolbox Estatístico

- Test chi quadrado: teste de aderência,
- Se  $CHSQ > \text{Chi2inv}(\alpha\%, v)$  rejeita  $H_0$ : os dados empíricos se ajustam à distribuição no teste.

```
>>[chsq,prob,df] =Chstest(rettnlp4,[mean(rettnlp4),std(rettnlp4)])  
>>chi2inv(0.01,47)
```

---

---

---

---

---

---

---

---

## Exemplos

Para calcular o VaR com probabilidade 1-alpha

```
>> X = NORMINV(1-alpha,MU,SIGMA)
```

Para ajustar dados do vetor X a uma normal e construir intervalos de confiança ao 100\*(1-alpha)% de confiança

```
>> NORMFIT(X,ALPHA)
```

---

---

---

---

---

---

---

---

## Toolbox Otimização

FMINCON resolve problemas da forma:

min  $F(X)$  sujeito a:

$A * X \leq B$ ,  $A_{eq} * X = B_{eq}$  (restrições lineares)

$C(X) \leq 0$ ,  $C_{eq}(X) = 0$  (restrições não lineares)

$LB \leq X \leq UB$  (limites)

$X = \text{FMINCON}(\text{FUN}, X_0, A, B)$  começa em  $X_0$  e encontra o mínimo  $X$  da função  $\text{FUN}$ , sujeita a desigualdade linear  $A * X \leq B$ . ( $X$  é um vetor)

---

---

---

---

---

---

---

---

## Toolbox Otimização

$X = \text{FMINCON}(\text{FUN}, X_0, A, B, \text{Aeq}, \text{Beq}, \text{LB}, \text{UB}, \text{NONLCON})$

Sujeita a minimização as restrições definidas na função NONLCON. A função NONLCON aceita  $X$  e retorna os vetores  $C$  e  $\text{Ceq}$ , que representam as desigualdades e igualdades não lineares, respetivamente

Caso alguma restrição não exista basta definir o campo com [].

---

---

---

---

---

---

---

---

## Toolbox Otimização

Exemplo: minimize a função:

$3\sin(x) + \exp(y)$ , com  $x, y \geq 0$ ;

```
>X=fmincon(@inline('3*sin(x(1))+exp(x(2))'), [1;1], [], [], [], [], [0 0])
```

Dará

$X = [0;0]$ . Confirará graficamente.

---

---

---

---

---

---

---

---

## Toolbox Finance

$V = \text{BLSIMPV}(\text{So}, X, R, T, \text{CALL}, \text{MAXITER}, Q, \text{TOL})$

retorna a volatilidade implícita do ativo subjacente dado o preço corrente  $\text{So}$ , o preço de exercício  $X$ , a taxa livre de risco  $R$ , o tempo para a maturidade  $T$ ,  $E$  o valor da opção call.  $\text{MAXITER}$  é o número máximo de iterações usado para encontrar  $V$ .

---

---

---

---

---

---

---

---

## Exemplo

- Um ativo tem preço hoje de R\$100, um preço de exercício de R\$95, a taxa livre de risco é 7.5% e o tempo para a maturidade da opção é .25 anos. A opção tem um valor de mercado de \$10.00. Qual é a volatilidade implícita do ativo?

```
>> blsimpv(100,95, .075, .25,10)
```

---

---

---

---

---

---

---

---

## Toolbox Finance

- FRONTIER(Ativo,RET)  
Esta função gráfica a fronteira eficiente.  
Ativo é uma matriz M-por-N contendo os dados de N ativos para M datas diferentes  
RET é um vetor 1-por-N vector contendo as taxas de retorno de cada ativo.

---

---

---

---

---

---

---

---

## Toolbox Finance

```
>> cd e:/Oppencad  
>> load ativo  
>> retativo=log(ativo(2:end,:))-  
log(ativo(1:end-1,:));  
>> e=mean(retativo)  
>> frontier(retativo,e)
```

---

---

---

---

---

---

---

---

## Toolbox Finance

$V = \text{PORTVAR}(\text{ASSET}, \text{WS})$

Retorna a variância da carteira formada pelos ativos contidos em

ASSET que é uma matriz  $M \times N$  com os dados dos ativos e WS é um vetor  $1 \times N$  com os correspondentes pesos.

---

---

---

---

---

---

---

---

## Toolbox Series Temporais

- Teste dos resíduos serem I. I.D Normais

```
>>archtest(residuals , Lags , alpha)
```

Exemplo:

```
>>e=randn(1,1000);
```

```
>>archtest(e,1,0.01);
```

```
>>autocorr(e , 1 )
```

---

---

---

---

---

---

---

---

## Toolbox Series Temporais

- `garchfit(Spec, Series)`
- Series – Vetor com as observações da variável de interesse univariada.
- Spec: é a especificação do modelo por exemplo se queremos ajustar os dados a um `garch(3,2)` temos que fazer

```
>> spec = garchset('P',3,'Q',2)
```

A que melhor se ajusta a dados financeiros `garch(1,1)`

- `LBQTEST` Ljung-Box Q-statistic test.

```
>>Lbqtest(rettnlp4)
```

---

---

---

---

---


---

---

---

# Distribuições não-Gaussianas

## Vale 5




---

---

---

---

---

---

---


---

---

---

# Escala Log

## Vale 5




---

---

---

---

---

---

---

---

---

---

# Distribuições Generalizadas Hiperbólicas

The density probability function of the one dimensional GHD is defined by the following equation:

$$gh(x; \alpha, \beta, \delta, \mu, \lambda) = a(\lambda, \alpha, \beta, \delta) (\delta^2 + (x - \mu)^2)^{\frac{(\lambda-2)}{2}} K(\lambda, \alpha, \delta, \mu, \beta)$$

with,

$$K(\lambda, \alpha, \delta, \mu, \beta) = K_{\lambda-\frac{1}{2}}(\alpha\sqrt{\delta^2 + (x - \mu)^2}) \exp(\beta(x - \mu))$$

where,

$$a(\lambda, \alpha, \beta, \delta) = \frac{(\alpha^2 - \beta^2)^{\frac{\lambda}{2}}}{\sqrt{2\pi} \alpha^{(\lambda-\frac{1}{2})} \delta^\lambda K_\lambda(\delta\sqrt{\alpha^2 - \beta^2})}$$

is a norming factor to make the curve area total 1 and

$$K_\lambda(x) = \frac{1}{2} \int_0^\infty y^{\lambda-1} \exp\left(-\frac{1}{2}x(y + y^{-1})\right) dy$$

is the modified Bessel function<sup>2</sup> of third kind with index  $\lambda$ . The parameters domain are:

$$\begin{aligned} \mu, \lambda &\in \mathbb{R} \\ -\alpha < \beta < \alpha \\ \delta, \alpha &> 0. \end{aligned}$$

---

---

---

---

---

---

---

---

---

---

## Distribuições Generalizadas Hiperbólicas

Estas distribuições possuem caudas semi grossas:

$$gh(x; \lambda, \alpha, \beta, \delta) \sim |x|^{\lambda-1} \exp((\mp\alpha + \beta)x) \text{ as } x \rightarrow \pm\infty$$

Dos subclasses muito utilizadas são a Hyperbolica( $\lambda=1$ ) e a Normal Inversa gaussiana ( $\lambda=-0.5$ ):

$$hyp(x; \alpha, \beta, \delta, \mu) = \frac{\sqrt{\alpha^2 - \beta^2}}{2\delta\alpha K_1(\delta\sqrt{\alpha^2 - \beta^2})} \exp\left(-\alpha\sqrt{\delta^2 + (x - \mu)^2} + \beta(x - \mu)\right)$$

$$nig(x; \alpha, \beta, \delta, \mu) = \frac{\alpha\delta}{\pi} \exp\left(\delta\sqrt{\alpha^2 - \beta^2} + \beta(x - \mu)\right) \frac{K_1\left(\alpha\sqrt{\delta^2 + (x - \mu)^2}\right)}{\sqrt{\delta^2 + (x - \mu)^2}}$$

---

---

---

---

---

---

---

---

---

---

## Distribuições Generalizadas Hiperbólicas

Table 1. Sample

Asset	Ticker	Start	End
Banco Itaú - PN	Itaú4	07/01/1994	12/13/2001
Banco do Brasil - PN	Bbas4	07/01/1994	12/13/2001
Bradesco - PN	Bbdc4	07/01/1994	12/13/2001
Cemig - PN	Cmig4	07/01/1994	12/13/2001
Cia Siderúrgica Nacional - ON	Csua3	07/01/1994	12/13/2001
Eletrobrás - PNB	Elet6	07/01/1994	12/13/2001
Embratel Participações - PN	Ebtp4	09/21/1998	12/13/2001
Ibovespa	Ibvsp	07/01/1994	12/13/2001
Petrobrás - PN	Petr4	07/01/1994	12/13/2001
Petrobrás Distribuidora - PN	Brdt4	07/04/1994	12/13/2001
Tele Celular Sul - PN	Tesl4	09/21/1998	12/13/2001
Tele Nordeste Celular - PN	Tnep4	09/21/1998	12/13/2001
Telemar - PN	Tmlp4	09/22/1998	12/13/2001
Telesp - PN	Tlpp4	07/01/1994	12/13/2001
Vale do Rio Doce - PNA	Vale5	07/01/1994	12/13/2001

---

---

---

---

---

---

---

---

---

---

## Distribuições Generalizadas Hiperbólicas

- A estimação dos parâmetros da distribuição será feita via máxima Verosimilhanças:

$$L = \sum_{i=1}^n \log(gh(x_i; \alpha, \beta, \delta, \mu, \lambda))$$

Isto é, encontraremos os parametro que maximizem a Função  $L$ ,  $n$  é o tamanho da amostra. (Minimos Quadrados?)

```
>>>parametros=GhFit(Empirica,Lambda)
>>>parametros=GhFit(retnlp4,-0.5)%para NIG
>>>[chsq,prob,df] =Chstest(retnlp4,parametros)
```

---

---

---

---

---

---

---

---

---

---

## Distribuições Generalizadas Hiperbólicas

Table 3. Estimated NIG parameters.

Sample	$\alpha$	$\beta$	$\delta$	$\mu$	LLH
Bbas4	26.1863	3.3516	0.0356	-0.0049	3512.65
Bbde4	25.2340	0.0027	0.0234	0	3978.71
Brdt4	36.7793	3.7894	0.0325	-0.0029	3922.97
Cmig4	27.0195	0.0008	0.0327	0.0003	3681.63
Csna3	25.3325	2.4753	0.0236	-0.0015	3949.86
Ebtp4	22.8770	3.7054	0.0424	-0.0075	1412.84
Elet6	23.6626	0.0034	0.0343	0	3532.29
Ibvsp	31.9096	-0.0035	0.0233	0.0012	4178.17
Itau4	30.7352	0.0015	0.0249	0.0008	4065.40
Petr4	25.3411	0.0009	0.0285	0.0007	3764.37
Tesl4	24.5055	-0.0003	0.0556	0.0012	1327.02
Tlpp4	20.3812	0.0038	0.0249	0.0003	3763.65
Tnep4	21.8374	0.0013	0.0519	0.0012	1317.41
Tnlp4	26.2133	0.0010	0.0384	0.0004	1505.29
Vale5	26.6233	0.0048	0.0249	0	3956.39

## Teste de Adherencia

```
>>par=GHFit(rettnlp4,-0.5)%para NIG
>>parametro= [par.Alfá, par.Beta, par.Delta, par.Mu,par.Lambda],
>>[STA,P,DF]=ChTest(rettnlp4,parametro,20)
>>c=chi2inv(0.05,19)

>>distancias.m
```

## VaR

- Quando estamos usando value-at-risk (VaR), o administrador de uma carteira de instrumentos financeiros esta interessado em fazer uma afirmação da seguinte forma:

“Estamos  $\alpha$  nível de certeza que não vamos perder mas do que  $V$  reais nos próximos  $N$  dias”

A variável  $V$  é o VaR da carteira, isto é função de dois parâmetros:  $N$  o horizonte de tempo e  $\alpha$  o nível de confiança.



## Introdução

- Na prática analistas escolhem  $N=1$ , devido a que não existem suficientes dados para fazer uma boa estimativa para períodos maiores.
- A hipótese usual é:

$$\text{VaR para } N \text{ dias} = \text{VaR de 1 dia} * (N)^{1/2}$$

Isto é verdadeiro quando as mudanças consecutivas na carteira são independentes e identicamente Normais.

---

---

---

---

---

---

---

---

## Simulação Histórica

- Crie uma base de dados diária de todas as variáveis de mercado que afetam a carteira.
- O primeiro cenário supõe que as mudanças em todas as variáveis de mercado para amanhã serão como aconteceu no primeiro dia da base de dados
- O segundo cenário supõe que as mudanças em todas as variáveis de mercado para amanhã serão como aconteceu no segundo dia da base de dados
- E assim sucessivamente..

---

---

---

---

---

---

---

---

## Simulação Histórica

- Suponha que temos  $m$  dias na base de dados
- Seja  $v_i$  o valor da variável de mercado no dia  $i$
- Existirão  $m-1$  possíveis cenários
- O  $i$ -ésimo cenário supõe que o valor da variável de mercado amanhã (i.e., no dia  $m+1$ ) é :

$$v_m = \frac{v_i}{v_{i-1}}$$

---

---

---

---

---

---

---

---

## Simulação Historica

- Em cada possível cenário calculamos a variação do valor da carteira.
- Agora rankeamos estas variações e a que esteja no 0.01m pior lugar será o VaR de 1 dia a 99% de certeza.
- Exem: se  $m=500$ , o VaR 1 dia a 99% será o pior 5to lugar. Das possíveis variações.
- Apartir daqui a gente a cada dia faz uma janela movil de 500 dias e faz o recalculo do VaR.
- Ver *hsvar.m*

---

---

---

---

---

---

---

---

## Bootstrapping com carteiras

Para calcular VaR temos que:

- Encontrar o valor da carteira hoje
- Fazer uma amostragem usando um sorteio aleatorio dos proximos  $\delta x_i$ .
- Reavaliar a carteira no fim

---

---

---

---

---

---

---

---

## Bootstrapping com carteiras

- Calcular a variação da carteira  $\delta P$
- Fazer esta amostragem varias vezes ate' construir uma distribuição de probabilidade para  $\delta P$
- E o VaR será determinado da seguinte forma:
- Se por exemplo fazemos 1,000 simulações

---

---

---

---

---

---

---

---

## Bootstrapping com carteiras

- Fazer no Matlab

```
>>bootstrapvar(rettnlp4,1000,0.99)
```

---

---

---

---

---

---

---

---

## Método Variância-Covariância

- Imagine que temos uma carteira com 2 ativos, com volatilidades diárias de 1% e 2%, a correlação é 0.7, e os pesos são 2/3 e 1/3. Assumindo que o valor da carteira seja 10 milhões. Encontrar o VaR com um horizonte de tempo de 10 dias.

---

---

---

---

---

---

---

---

## Método Variância-Covariância

```
>>format bank  
>>s1=0.02*sqrt(10);  
>>s2=0.01*sqrt(10);  
>>Covc=[s1^2 0.7*s1*s2;0.7*s1*s2 s2^2];  
>>s=PortStats([0 0],covc,[2/3 1/3]);  
>>VaR=portvrisk(0,s,0.01,10^7)
```

Replicar para outros ativos

---

---

---

---

---

---

---

---

## Stress Testing

- Esto requer testar quão bom seria o comportamento de uma carteira baixo os movimentos mas extremos observados no mercado durante os últimos 10 a 20 anos

---

---

---

---

---

---

---

---

## Back Testing

- Este processo é muito importante, ele envolve testar quão boa foi a performance do VaR no passado.
- Suponha que estamos calculando o VaR de 1 dia ao 99%. O BackTesting resulta em observar quantas vezes uma perda num dia excedeu o VaR de 99% calculado para esse dia. Se isto acontece cerca de 1% dos dias, podemos sentirnos seguros com a metodologia usada para calcular VaR.
- E se acontece por exemplo 7% devemos ficar muito desconfiados se a metodologia usada é adequada.

---

---

---

---

---

---

---

---

## Backtesting

>>kupiebacktest(rettnlp4,0.0559,0.99)

---

---

---

---

---

---

---

---

## Outros Backtestings

- Lopezbacktest.m
  - Blancoilhebacktest.m
  
  - Frechetvar.m
  - Tvar.m
- ```
>>tvar(mean(rettnlp4),std(rettnlp4),5,0.99,1)
```
- BacktestingGH.m

---

---

---

---

---


---

---

---

## VaR - GH

### VaR - Vale do Rio Doce



---

---

---

---

---

---

---

---

## Volatilidade Estocástica

- Como vimos anteriormente precisamos estimar a volatilidade para obter o VaR, uma forma de estimar esta volatilidade é:
- Defina  $\sigma_n$  como a volatilidade diaria entre os dias  $n-1$  e o dia  $n$ , estimada no fim do dia  $n-1$
- Defina  $S_i$  como o valor da variável de mercado no fim do dia  $i$
- Defina  $u_i = \ln(S_i/S_{i-1})$  e

$$\sigma_n^2 = \frac{1}{m-1} \sum_{i=1}^m (u_{n-i} - \bar{u})^2$$
$$\bar{u} = \frac{1}{m} \sum_{i=1}^m u_{n-i}$$

---

---

---

---

---

---

---

---

## Volatilidade Estocástica

Uma simplificação usual no calculo do VaR é:

- Defina  $u_i$  como  $(S_i - S_{i-1})/S_{i-1}$
- Assuma que a média de  $u_i$  é zero
- Reemplaze  $m-1$  por  $m$

Isto dá 
$$\sigma_n^2 = \frac{1}{m} \sum_{i=1}^m u_{n-i}^2$$

---

---

---

---

---

---

---

---

## Volatilidade com Ponderações

Agora no lugar de asinar pesos iguais às observações podemos fazer o seguinte:

$$\sigma_n^2 = \sum_{i=1}^m \alpha_i u_{n-i}^2$$

onde

$$\sum_{i=1}^m \alpha_i = 1$$

---

---

---

---

---

---

---

---

## Modelo ARCH(m)

Num modelo ARCH(m) tambem asinamos algum peso a taxa da variancia de longo prazo,  $V_L$ :

$$\sigma_n^2 = \gamma V_L + \sum_{i=1}^m \alpha_i u_{n-i}^2$$

where

$$\gamma + \sum_{i=1}^m \alpha_i = 1$$

---

---

---

---

---

---

---

---

## Modelo EWMA (Exponentially Weighted Moving Average)

- Este modelo é um caso particular do modelo com ponderações, onde os pesos decaem exponencialmente quando nos movemos no sentido contrário ao tempo.
- Isto é tomando  $m$  suficientemente grande e  $\alpha_i = (1 - \lambda)\lambda^{i-1}$

Temos

$$\sigma_n^2 = \lambda \sigma_{n-1}^2 + (1 - \lambda) u_{n-1}^2$$

Isto é a volatilidade dependerá da estimativa feita no dia anterior e a mudança mas recente no retorno da variável de mercado  $u$ .

---

---

---

---

---

---

---

---

## Exemplo: EWMA

- Suponha que  $\lambda=0.90$ , e que a volatilidade estimada para o dia  $n-1$  seja 1% por dia e durante o dia  $n-1$  a variável de mercado tenha aumentado um 2%.
- Isto significa que  $\sigma_{n-1}^2 = 0.01^2 = 0.0001$  e  $u_{n-1}^2 = 0.02^2 = 0.0004$ , daqui:

$$\sigma_n^2 = 0.90 \times 0.0001 + 0.10 \times 0.0004 = 0.00013$$

Ou seja  $\sigma_n$  é 1,14% por dia.

O sistema RiskMetrics desenvolvido pela J.P.Morgan disponibilizado em 1994, usa  $\lambda=0.94$ , para fazer o update das estimativas de volatilidade.

---

---

---

---

---

---

---

---

## GARCH(1,1)

No modelo GARCH (1,1) assinamos algum peso taxa da variancia de longo prazo,  $V_L$ .

$$\sigma_n^2 = \gamma V_L + \alpha u_{n-1}^2 + \beta \sigma_{n-1}^2$$

Como os pesos somam 1:

$$\gamma + \alpha + \beta = 1$$

---

---

---

---

---

---

---

---

## GARCH(1,1)

Fazendo  $\omega = \gamma V$ , O modelo GARCH (1,1) é:

$$\sigma_n^2 = \omega + \alpha u_{n-1}^2 + \beta \sigma_{n-1}^2$$

E

$$V_L = \frac{\omega}{1 - \alpha - \beta}$$

---

---

---

---

---

---

---

---

## Exemplo

- Suponha

$$\sigma_n^2 = 0.000002 + 0.13u_{n-1}^2 + 0.86\sigma_{n-1}^2$$

- A taxa de variancia de longo prazo é 0.0002  
daqui a taxa de volatilidade diaria de longo  
prazo é 1.4%

---

---

---

---

---

---

---

---

## Exemplo

- Suponha que a estimativa atual para a volatilidade seja 1.6% por dia e o percentagem de mudança na variável de mercado atual seja 1%.
- A nova taxa de variância será

E a nova volatilidade é 1.53% por dia  
 $0.000002 + 0.13 \times 0.0001 + 0.86 \times 0.000256 = 0.00023336$

Ver toolbox GARCH Matlab

---

---

---

---

---

---

---

---



## Toolbox GARCH

- GARCH(1,1)

$$y_t = C + \varepsilon_t$$

$$\sigma_t^2 = \kappa + G_1 \sigma_{t-1}^2 + A_1 \varepsilon_{t-1}^2$$

- GARCH(p,q)

$$\sigma_t^2 = \kappa + \sum_{i=1}^P G_i \sigma_{t-i}^2 + \sum_{j=1}^Q A_j \varepsilon_{t-j}^2$$

---

---

---

---

---

---

---

---

## GARCH(1,1)

```
>>spec = garchset('P',1,'Q',1);  
>> garchfit(spec,rettnlp4)
```

---

---

---

---

---

---

---

---

## Opções

- EssherEst.m, Momento.m

```
>>par=GHFit(rettnlp4,-0.5)%para NIG  
>>parametro= [par.Alfa, par.Beta, par.Delta,  
par.Mu,par.Lambda, 0.16];  
>> EscherEst(0.2,parametro)  
>>v=fminsearch('EscherEst(x,[99.4587,-  
0.0005,0.0543,0.0013,-0.5000,0.1600])',1)
```

- Convolucao.m
- InvFourier.m

---

---

---

---

---

---

---

---

## Opções

- NigCallEssher.m

```
>>NigCallEsscher(34,0.16, 99.4587,-  
0.0005,0.0543,0.0013,-0.5000,38,38.59,4096,0.2)
```

```
>>Blsprecoc(38.59,38,0.16,34/365,0.37)
```

---

---

---

---

---

---

---

---

## Opção da Vale




Fig. 4. Black and Scholes minus GHD Vale do Rio Doce Call prices for various maturities and strike prices.

---

---

---

---

---

---

---

---

## Bibliografia

- <http://professores.ibmecrj.br/pepe>

---

---

---

---

---

---

---

---